

## **Использование искусственных нейронных сетей для прогнозирования американского фондового рынка в период кризиса**

Мировой финансовый кризис 2008 года стал потрясением для инвесторов, потому что за крайне короткий промежуток времени они были вынуждены нести значительные финансовые потери, многие практически полностью лишились своих капиталов. Однако, как говорит теория, процессы, происходящие на фондовом рынке, являются игрой «с нулевой суммой». Иными словами, там, где одни инвесторы вынуждены подсчитывать фантастические убытки, другие игроки рынка получают сопоставимые прибыли. Отсюда очевидна потребность инвестиционного сообщества в прогнозировании падающего, даже обрушающегося рынка. И дело здесь не только в спекулятивных мотивах, но и в необходимости иметь стратегию, которая бы в значительной степени хеджировала риски потерь капитала в условиях сильного медвежьего тренда.

В рамках данной статьи мы попытаемся построить торговую стратегию для прогнозирования американского фондового рынка на в период его наиболее резкого падения во время кризиса. Для достижения этой цели мы будем использовать методы искусственных нейронных сетей – инструмент, получивший в последние годы широкое распространение при обработке и прогнозировании данных как в финансовой математике, так и в смежных науках. При этом нашей целью будет являться хорошая прогнозная эффективность не только в период кризиса, но и на более долгосрочном временном промежутке в несколько лет.

### **Искусственные нейронные сети в финансах**

Искусственные нейронные сети являются попыткой сконструировать аналог биологических нейронных сетей головного мозга человека. Мозг – это децентрализованная структура, состоящая из миллиардов клеток-нейронов. Постоянно изменяющиеся во времени связи – это и есть нейронные сети, которые определяют механизм функционирования структуры. Эффективность биологических нейронных сетей столь высока, что их пытаются имитировать в различных областях науки, в том числе и в финансовом моделировании.

Данная задача хотя и является необычайно сложной, тем не менее открывает блестящие перспективы в понимании и прогнозировании фондового, валютного и других финансовых рынков, поскольку может пролить свет на то, каким образом участники рынка взаимодействуют друг с другом и влияют на процесс ценообразования. Таким образом, задача

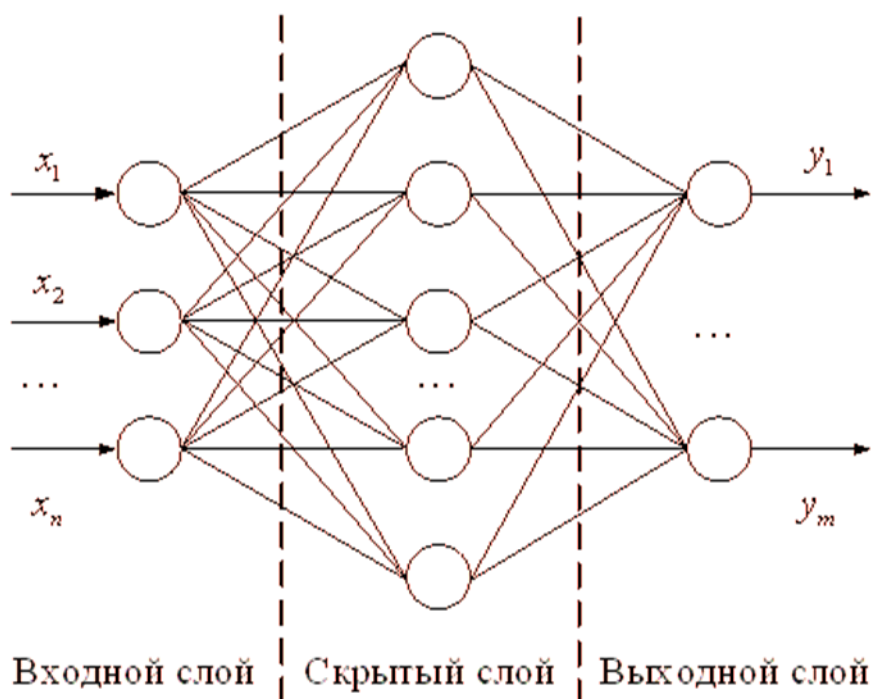
использования искусственных нейронных сетей на финансовом рынке в общем случае подразумевает создание механизма, который с достаточно высокой степенью точности воспроизводит поведение субъектов принятия решения.

Это крайне важная базовая предпосылка, которая основывается на предположении о том, что ценообразование на рынке – это не результат случайного блуждания – броуновского движения, но агрегированный результат решений многих отдельных индивидуумов, принятых на основе субъективных суждений. Броуновское движение – это случайный процесс с нормальным Гауссовым распределением, который получается – согласно центральной предельной теореме – как предельный переход при достаточно большом количестве взаимно независимых случайных процессов (ожиданий). Поэтому фигура лица, принимающего решения, выдвигается на передний план при том условии, что агрегированную динамику ценового процесса можно представить как протоколы решений некоего представительного агента, а не суммы разнородных независимых агентов. Подобная точка зрения открывает возможность для прогнозирования рынка, хотя ещё множество вопросов (таких как, например, выбор репрезентативного инвестора, кластеризация различных игроков и др.) требуют внимательного рассмотрения.

В рамках данной статьи мы будем пытаться построить модель поведения инвесторов на американском фондовом рынке в условиях падения (кризиса), а обоснованием верности нашей модели будет служить динамика виртуального инвестиционного портфеля, рассчитываемого на реальных исторических данных. Однако прежде чем перейти к прогнозированию рынка, необходимо изложить основы использования искусственных нейронных сетей в финансовом моделировании.

Во-первых, необходимо задать архитектуру искусственной нейронной сети. В общем виде архитектура выглядит так, как изображено на Рис. 1. Обычно в искусственной нейронной сети выделяют три группы слоёв: входной (он содержит исходные данные  $x$  – как правило, эмпирические значения), скрытые (их может быть несколько, и они определённым образом преобразуют данные, полученные из входного слоя) и выходной (значения  $y$  которого являются результатом работы сети).

Рис. 1

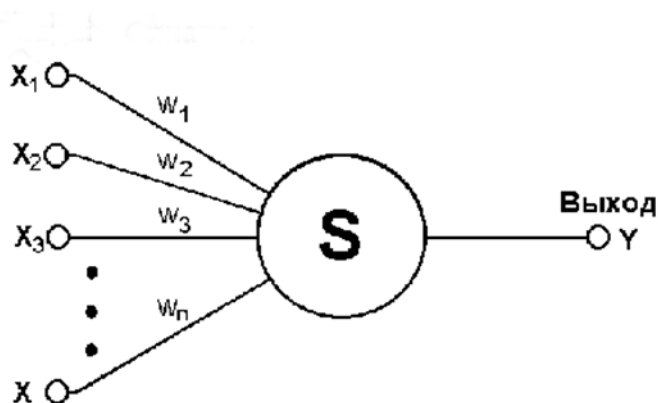


Стоит отметить, что отличительной особенностью конструкции искусственной нейронной сети является то, что входное значение для каждого нейрона скрытого слоя представляет собой взвешенную сумму  $S$  значений входного слоя (либо взвешенную сумму предыдущего скрытого слоя), Рис. 2.

Формально это положение запишем так (Выражение 1):

$$S = \sum_{i=1}^n X_i * w_i$$

Рис. 2



На первый взгляд может показаться, что мы имеем дело лишь со сложной регрессией с большим количеством коэффициентов, однако это не

так, потому что архитектура искусственной нейронной сети содержит в себе нелинейное преобразование. Это означает, что взвешенная сумма  $S$  каждого нейрона скрытого слоя является аргументом нелинейной функции  $f(S)$ , которая создаёт выходное значение скрытого слоя  $Y$  на Рис. 2.

То есть (Выражение 2):

$$Y = f(S)$$

Использование нелинейной функции преобразования также является отсылкой к биологическим нейронным сетям. В головном мозге человека нейрон, получая информацию от другого нейрона, определённым образом «решает», реагировать на неё, т.е. передавать сигнал дальше по нейронной сети, или нет. Это называется функцией активации нейрона, и обычно она является пороговой вида (Выражение 3):

$$f(S) = \begin{cases} 1 & \text{if } S > 0 \\ -1 & \text{otherwise} \end{cases}$$

Однако при построении искусственных нейронных сетей достаточно редко используют пороговую функцию активации, поскольку это затрудняет применение дифференциального исчисления. Вместо пороговой функции обычно применяют такие функции активации, область значений которых близка к пороговой.

В практических построениях популярны следующие нелинейные функции активации:

$$f(s) = \frac{1}{1 + e^{-s}} - \text{стандартная логистическая функция с областью значений } [0;1]$$

$$f(s) = \frac{e^s - e^{-s}}{e^s + e^{-s}} - \text{гиперболический тангенс с областью значений } [-1;1]$$

После того, как архитектура искусственной нейронной сети (количество слоёв, количество нейронов в них, функция активации нейронов скрытого слоя) определена, необходимо задать способ обучения сети. Под обучением искусственной нейронной сети подразумевается итеративный процесс оптимизации значений весов  $w$ , которые определяют связи между нейронами и общую эффективность работы сети. Итеративный процесс означает, что существует некая процедура, которая позволяет пошагово двигаться от начального (иногда случайного) значения к оптимуму.

Некоторые базовые принципы обучения можно почерпнуть из работы (Kröse, van der Smagt, 1996).

То, каким образом искусственная нейронная сеть обучается, является, пожалуй, наиболее сложным элементом данного процесса. Здесь не существует раз и навсегда определённых догм и правил, и поэтому нередко исследователи определяют наиболее эффективный способ обучения опытным путём. Тем не менее, можно выделить два основных подхода. Первый – это обучение «с учителем», когда искусственная нейронная сеть обучается на заранее представленном ей наборе примеров. Второй способ – самообучение. В этом случае сеть самостоятельно ищет оптимальные значения, не имея эталонных значений-примеров. В этом случае процесс обучения целиком зависит от внутренней спецификации сети.

Традиционно считается, что самообучающиеся нейронные сети более эффективны и дают более точные и корректные прогнозы, поскольку они учитывают одну из наиболее важных и значимых особенностей человеческого мозга – способность к самостоятельному обучению, обобщению и принятию решений.

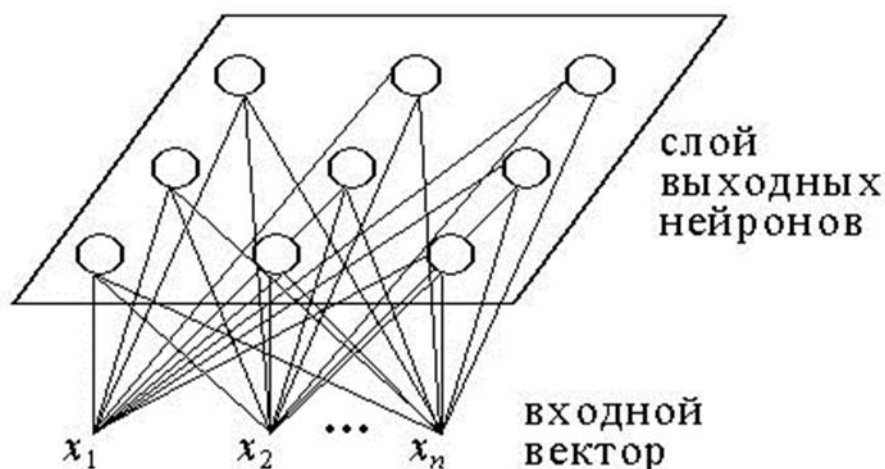
### **Наша модель**

При построении нашей модели для прогнозирования рынка в условиях кризиса мы обратимся к картам самоорганизации (также называемой сетью Кохонена), детальное описание которых можно найти, например, в работах [(Хайкин, 2006, (Kohonen, 1982, 1990, 1997))]. Эта сеть примечательна тем, что в основе её построения лежит принцип изменяющихся связей (ослабление, усиление) между нейронами во времени, что соответствует представлениям о функционировании нейронных сетей головного мозга человека.

Карты самоорганизации в плане архитектуры представляют собой несколько иную структуру, чем изображённая на Рис.1. По сути, в картах самоорганизации речь идёт о различных отображениях исходных векторов-

сигналов в пространстве выходного слоя, который имеет большую размерность (Рис. 3).

Рис. 3



Карты самоорганизации являются самообучающейся нейронной сетью. Отображения исходного вектора (или векторов) конкурируют между собой, в результате чего и происходит оптимизация векторов-отображений. Важно отметить, что оптимизация отображений производится не на основе сравнения с обучающим примером-эталоном (как, например, при использовании метода наименьших квадратов), а благодаря конкуренции между несколькими векторами-отображениями, в результате чего достигается эффективность функционирования сети.

В процессе конкуренции определяется отображение-«победитель», которое задаёт пространство кооперации для остальных отображений – то, каким образом, они должны изменить свои значения, чтобы максимально приблизиться к значениям отображения-«победителя». После этого происходит подстройка – адаптация других отображений под эти значения.

Если попытаться представить итеративный процесс оптимизации карт самоорганизации пошагово, то он будет выглядеть так:

1. Случайным образом задаются отображения исходного вектора  $X$ .

Сразу оговоримся, что в данной работе мы будем использовать один входной вектор, состоящий из пяти значений.

2. Осуществляется поиск отображения-«победителя» (процесс конкуренции), т.е. того вектора, который наиболее близок по значению к исходному вектору  $X$ . Победителем признаётся то отображение, которое обладает наименьшим Евклидовым расстоянием по отношению к исходному вектору  $X$ .
3. Производится подстройка других отображений под отображение-«победитель» (процессы кооперации и адаптации) с помощью следующей итеративной процедуры обучения (Выражение 4):

$$w_n^j = w_{n-1}^j + \eta * e^{\frac{-n}{\tau_1}} * e^{\frac{-[w_{n-1}^j - w_{n-1}^{win}]^2}{2 \left( \sigma * e^{\frac{-n}{\tau_0}} \right)^2}} - [X - w_{n-1}^j],$$

Где,

$X$  – исходный эмпирический вектор,

$w$  – вектор-отображение,

$j$  – номер вектора-отображения,

$n$  – число итераций, в течение которых производится обучение сети,

$w^{win}$  – номер отображения-«победителя» на данной итерации. Это

очень важное уточнение, потому что, строго говоря, в процессе

обучения на каждой итерации может быть разное отображение-

«победитель». Именно этот механизм и обеспечивает

самоорганизацию – непрерывное изменение связей нейронной сети во времени.

$\sigma$  – стандартное отклонение нормального (Гауссова) распределения.

Обратим внимание, что в основе данной итеративной функции лежит функция Гаусса, которая обеспечивает нелинейное преобразование в сети,

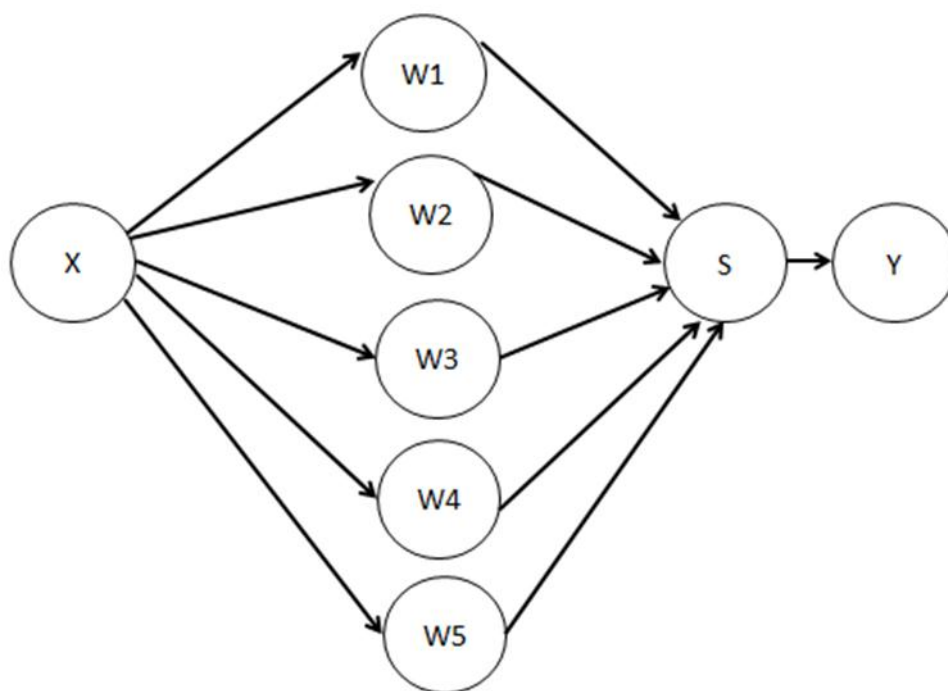
$\eta, \tau_1, \tau_2$  – параметры, влияющие на скорость обучения сети.

Однако после того как мы получили оптимизированные отображения вектора  $X$ , перед нами неизбежно встаёт вопрос интерпретации полученных данных. Напомним, мы хотели бы использовать результат работы сети для прогнозирования фондового рынка. В то же время после процедуры обучения и подстройки отображений мы получаем в выходном слое пять векторов вместо одного, т.е. 25 отдельных значений. С другой стороны, для прогнозирования динамики одного из инструментов фондового рынка (индекса или отдельной акции) было бы ценно получить одно скалярное значение, которое можно интерпретировать как сигнал на покупку или продажу этого инструмента.

Для получения такого скалярного значения мы введём ещё один дополнительный слой в нашу искусственную нейронную сеть. Входным значением этого слоя будет служить сумма векторных произведений исходного вектора  $X$  с каждым из его отображений  $w$ . Подобная операция уже даст нам скалярное значение в виде Выражения 1. Итоговое значение  $Y$ , которое будет использовано для прогноза, будет нами получено путём подставки этого скаляра в функцию активации (мы будем использовать гиперболический тангенс).

Таким образом, наша искусственная нейронная сеть примет следующий итоговый вид (Рис.4). Ещё раз отметим, что в отличие от Рис. 1  $X$  и  $w$  здесь являются векторами, а не скалярными значениями.

Рис. 4



### Первые эмпирические результаты

Прежде чем перейти к обзору результатов прогноза нашей модели, необходимо указать на данные, которые были использованы для тестирования карт самоорганизации. Мы предоставляли сети ежедневные логарифмированные значения доходностей американского фондового индекса Dow Jones за период с 27 мая 2007 года по 31 марта 2009 года, т.е. данные значения охватывали предкризисный период, дно кризиса и начало периода восстановления.

Наша гипотеза состоит в том, что если с помощью торговой стратегии, основанной на использовании карт самоорганизации, нам удастся превзойти рост рынка (а в нашем случае, скорее не упасть глубже, чем рынок), то это будет сигналом того, что данный алгоритм способен с некоторой степенью достоверности воспроизводить поведение участников рынка.

Под ростом или падением рынка мы будем понимать динамику доходности самого индекса Dow Jones во времени (рыночный портфель), при том, что в начале рассматриваемого периода мы принимали его значение равным 1 (обозначение на графиках Market) . Что касается портфеля,

формируемого на основе прогнозов искусственной нейронной сети карт самоорганизации (виртуальный инвестиционный портфель), то его значение на начало рассматриваемого периода также было равно 1. Далее, в зависимости от прогноза сети, мы ежедневно вставляли в длинную, либо в короткую позицию (обозначение на графиках Portf).

Исходный эмпирический вектор  $X$  определялся как пять последовательных логарифмированных значений доходности индекса Dow Jones с лагом в два дня по отношению ко дню прогноза. Начальные векторы-отображения мы получали из случайного нормального распределения, обладающего тем же средним и стандартным отклонением, что и эмпирическая выборка.

Необходимо также указать на то, что при расчете прогноза сети мы использовали метод «скользящего окна». Это означает, что при расчете прогноза для каждого последующего торгового дня, мы также на один день сдвигали «вправо» по временной оси наш исходный вектор  $X$ . Благодаря этому искусственная нейронная сеть карт самоорганизации постоянно обучалась на актуальной информации. Это крайне важно для прогнозирования финансовых рынков, где данные стремительно устаревают и становятся нерелевантными.

Наша торговая стратегия состояла в следующем: в случае, если абсолютное значение прогноза сети в торговый день  $k$  было больше или равно значению прогноза сети в торговый день  $k-1$ , мы вставляли в длинную позицию, в противном случае – в короткую. Следует отметить, что мы намеренно старались использовать достаточно примитивное торговое правило, для того чтобы, по возможности, минимизировать влияние самого торгового правила на общий результат.

Формально наше торговое правило выгляди так (Выражение 5):

$$G_k = \begin{cases} r_k & \text{if } \zeta_k \geq \zeta_{k-1} \\ -r_k & \text{otherwise} \end{cases}$$

Где,

$G_k$  - логарифмированная доходность виртуального инвестиционного портфеля в торговый день  $k$ ,

$r_k$  – логарифмированная доходность индекса Dow Jones в торговый день  $k$ ,

$\xi_k$  – скалярное значение прогноза нейронной сети для торгового дня  $k$ .

По итогам торговой сессии были получены интересные результаты. На конец рассматриваемого периода значение рыночного портфеля составило 0,57, а значение виртуального портфеля сильно варьировалось в зависимости от того, какими были исходные векторы-отображения. На Рис. 5,6,7 приведены некоторые результаты. По горизонтальной оси отложены торговые дни ( $k$ ), по вертикальной – величина портфеля.

Рис. 5

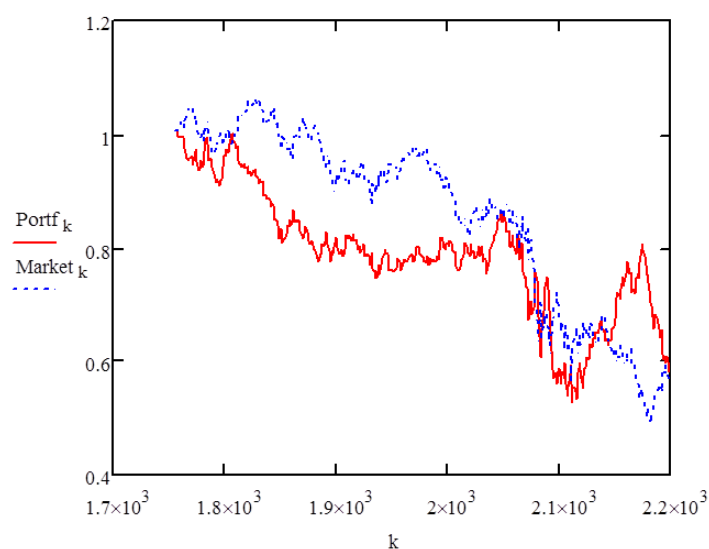


Рис. 6

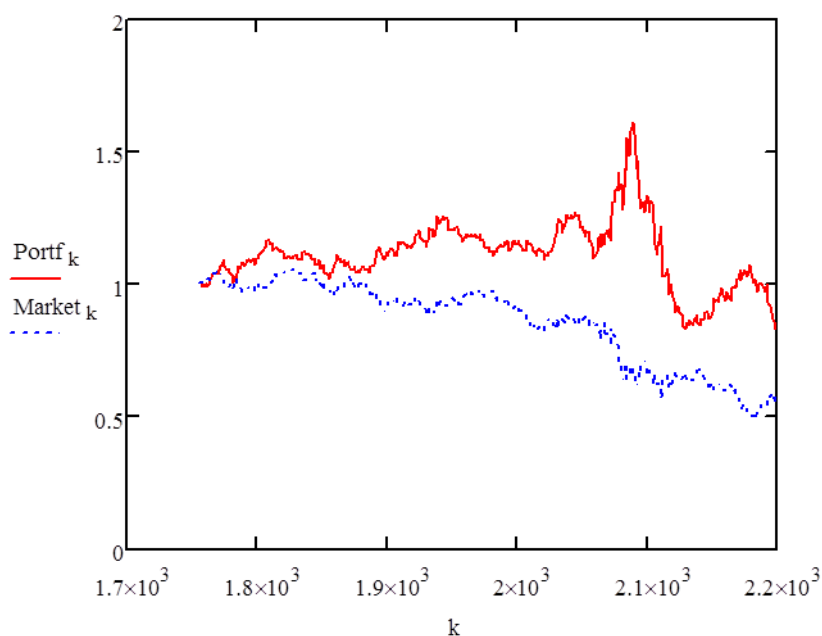
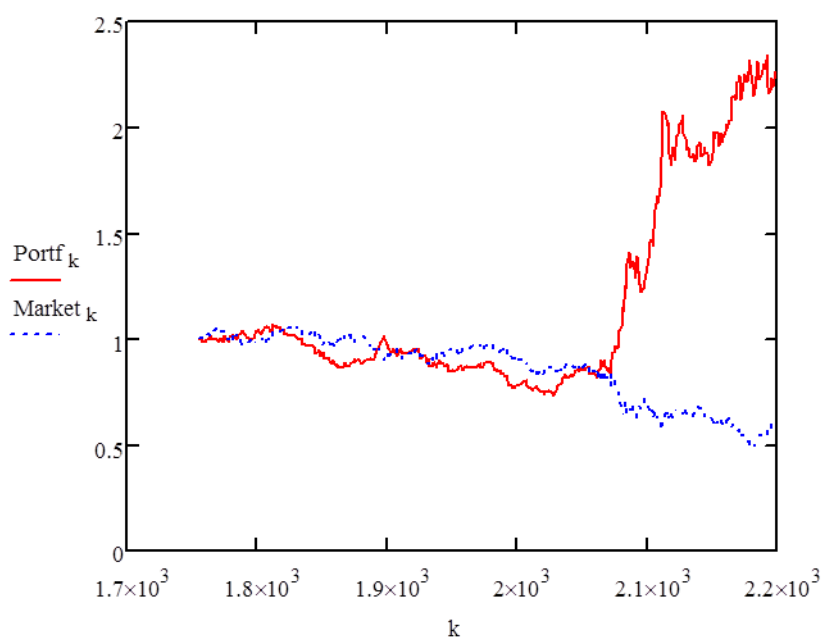


Рис. 7



Как видно из графиков, динамика виртуального инвестиционного портфеля очень сильно зависит от выбора начальных векторов-отображений: портфель ведёт себя хуже рынка, примерно наравне с ним или даже обыгрывает.

Данный результат наглядно демонстрирует две важные проблемы, связанные с использованием искусственных нейронных сетей в финансовом

моделировании. С одной стороны, в ходе итеративной процедуры оптимизации, крайне важным оказывается выбор начальной точки, т.е. «места», из которого мы начинаем улучшать функционирование сети. С другой стороны, для подбора случайных значений векторов-отображений мы вынуждены прибегать к генератору случайных значений, установленного в программное обеспечение, которое мы используем для расчетов (в данном случае, программу MachCAD). При этом идеальный генератор случайных чисел создать практически невозможно, а значит, наши начальные векторы-отображения будут в меньшей или большей степени детерминированы используемым ПО.

Как результат этих двух обстоятельств, мы не можем адекватно оценить эффективность работы карт самоорганизации. Более того, если подойти с позиции инвестора, то его, безусловно, не могут устроить такие значительные колебания портфеля в зависимости от «случайно» выбранных начальных значений.

### **Усовершенствование модели – удаление случайной составляющей в начальных данных**

Для того чтобы адекватно оценить эффективность карт самоорганизации на падающем рынке, нам необходимо убрать или минимизировать влияние случайной начальной составляющей на процесс оптимизации. Чтобы добиться этого, следует иначе задавать начальные значения векторов-отображений, чего можно достичь, используя методы предварительной обработки данных перед их представлением сети.

На сегодняшний день существует несколько методов предварительной обработки данных. В рамках данной работы мы обратились к двум из них – методу главных компонент (Principal Component Analysis, см., например, работу (Jolliffe, 2002)) и методу независимых компонент (Independent Component Analysis, см., например, работу (Hyvärinen, 2002)).

Данные два подхода имеют как существенные концептуальные различия, так и расчетные механизмы. Однако оба используются в том

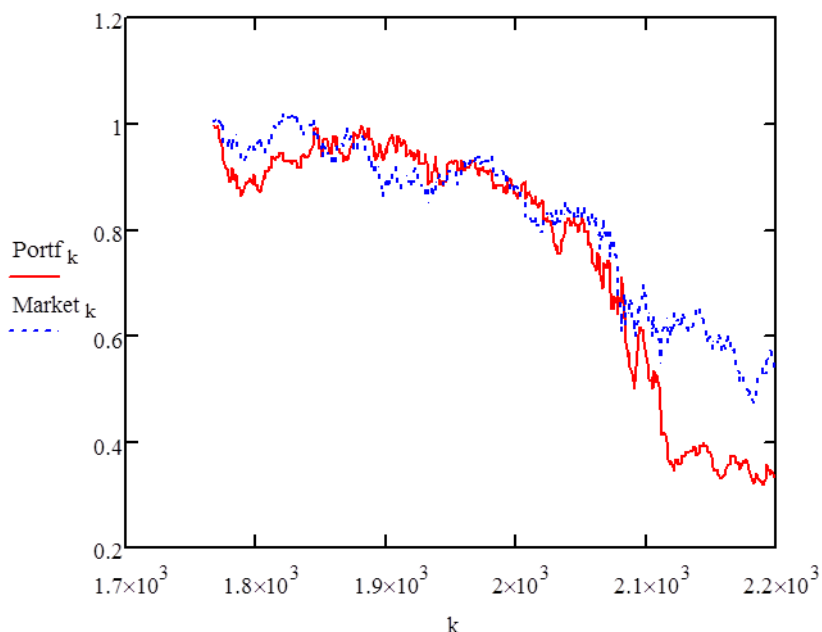
случае, когда нужно снизить размерность эмпирических данных (с сохранением значимой информации о временном ряде) и, что более важно для нас, отобразить их на координаты в другом пространстве. В случае с методом главных компонент – это проецирование эмпирического вектора на новые координатные оси, вдоль которых его дисперсия максимальна. В случае с методом независимых компонент – это проецирование эмпирического вектора на наиболее «интересные» координатные оси, иными словами, речь идёт о максимизации информации, содержащейся во временном ряде.

В обоих методах для отображения эмпирических данных в новом пространстве используются специальные кодирующие матрицы (ковариационная матрица в методе главных компонент и т.н. демикширующая матрица в методе независимых компонент). Мы попробуем взять именно эту кодирующую матрицу (предварительно сделав так, чтобы её размерность соответствовала длине нашего исходного вектора  $X$ ) в качестве начального набора векторов-отображений.

После того как мы удалили случайную составляющую в задании начальных векторов-отображений, мы вновь попробуем спрогнозировать рынок. Следует отметить, что в ходе применения методов главных и независимых компонент первый показал значительно более высокую результативность в прогнозировании рынка, поэтому в данной работе приводятся результаты только с применением метода главных компонент.

На Рис. 8 приведена сравнительная динамика рыночного и виртуального портфеля. По горизонтальной оси отложены торговые дни ( $k$ ), по вертикальной – величина портфеля.

Рис.8



Результат, который мы получили, вновь не может быть признан удовлетворительным ни с инвестиционной точки зрения, ни с точки зрения понимания процессов ценообразования на падающем рынке, поскольку виртуальный инвестиционный портфель «упал» ещё глубже рынка. Это означает, что наш алгоритм опять нуждается в доработке. Вместе с этим задача удаления случайной составляющей в задании начальных векторов-отображений была выполнена.

### **Усовершенствование модели – повышение эффективности обучения**

Чтобы повысить прогнозную эффективность нашей нейронной сети, мы попытаемся усовершенствовать процесс её обучения. До сих пор в качестве исходного вектора  $X$  мы брали вектор из пяти последовательных логарифмированных доходностей индекса Dow Jones с лагом в два дня по отношению ко дню торговли. Именно на основе этой информации осуществлялась оптимизация работы сети, а затем принималось инвестиционное решение (длинная или короткая позиция).

Теперь мы попробуем несколько изменить это алгоритм. Логично предположить, что для того, чтобы повысить прогнозную эффективность

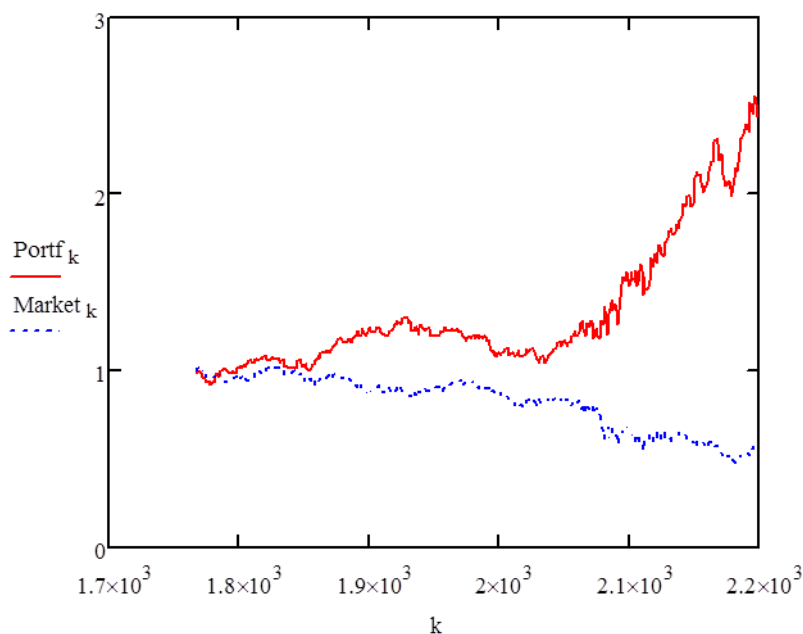
сети, она должна, как минимум, предсказывать наибольший рост или падение на рынке – «выбросы» во временном ряде – и одновременно игнорировать шумовую компоненту. Для реализации этой цели мы изменим способ задания исходного вектора  $X$ , из которого с помощью метода главных компонент затем будут сформированы начальные векторы-отображения.

Для определения исходного вектора  $X$  мы будем рассматривать временной период за 15 дней до торгового дня. Внутри этого временного отрезка мы находим день с максимальным абсолютным логарифмированным приростом индекса, а затем формируем начальный вектор  $X$  как вектор из пяти последовательных значений, предшествующих дню максимума. После этого мы проводим итеративную процедуру обучения сети, описанную выше.

Однако это является лишь первым этапом обучения, «обучением на максимуме». После его завершения мы переходим ко второму этапу – «обучению на минимуме». На этот раз исходный вектор  $X$  формируется из пяти логарифмированных значений, предшествующих минимуму – наименьшему абсолютному приросту индекса Dow Jones на том же 15-ти дневном отрезке. Следует отметить, что на этом втором этапе мы не формируем начальные векторы-отображения заново, но используем те, которые были получены в процессе оптимизации первого этапа – «обучения на максимуме».

На Рис. 9 представлены результаты, полученные с помощью нашей сети после усовершенствования процесса обучения (архитектура сети и торговая стратегия не менялись). По горизонтальной оси отложены торговые дни ( $k$ ), по вертикальной – величина портфеля.

Рис. 9



Как видно из графика, нам удалось значительно превзойти рынок и обеспечить практически 150% рост виртуального портфеля в самый тяжёлый для фондового рынка период. На конец торговой сессии значение рыночного портфеля составило 0, 55, а портфеля, построенного на основе прогнозов сети, – 2,44.

Полученные результаты свидетельствуют о том, что карты самоорганизации могут являться эффективным инструментом для работы на падающем рынке. Более того, инвестиционный успех стратегии, основанной на использовании данной сети, говорит о том, что карты самоорганизации с некоторой степенью подобия воспроизводят поведение инвесторов на рынке.

### **Работа модели в долгосрочном периоде**

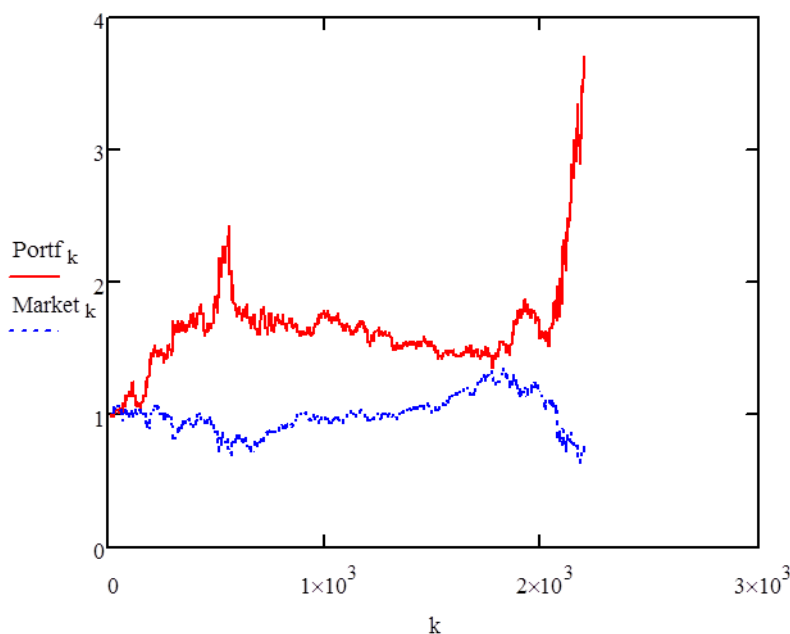
Искусственная нейронная сеть карт самоорганизации может быть использована в качестве эффективного инструмента падающего, кризисного рынка. Однако нам бы хотелось понять, можно ли использовать данную нейронную сеть на более длительном промежутке времени, фиксирующим не только падение, но и рост, а также общую смену режима функционирования рынка, обусловленного новыми законодательными инициативами, структурными и институциональными изменениями и другими факторами.

Здесь также стоит указать на одну интересную и небезосновательную точку зрения (см. работу (Евстигнеев, 2009)). Она заключается в том, что стремительное падение (как и взрывной рост) – в действительности более простая ситуация для участников рынка в плане принятия решений, а ситуация умеренного тренда или отсутствия значимых колебаний на рынке – более сложная. Это означает, что наша модель «научилась» работать в простых ситуациях, но не очень эффективна в сложных. При этом, справедливости ради, также стоит отметить, что периоды стремительных взлётов и падений краткосрочны на рынке. При грамотном выборе торговой стратегии инвестор может приумножить свой капитал в эти короткие периоды, однако для более длительной и эффективной работы на фондовом рынке необходимо иметь модель, которая будет успешно прогнозировать рынок и в периоды относительно спокойной динамики, которые и формируют картину фондового рынка в долгосрочной перспективе.

Чтобы оценить эффективность работы сети в долгосрочном периоде, мы представим ей более длинный массив данных – логарифмированные значения доходностей индекса Dow Jones с 30 июня 2000 года по 31 марта 2009 года.

На Рис. 10 представлены результаты работы нашей сети на этом практически десятилетнем массиве данных (архитектура сети и торговая стратегия не менялись). По горизонтальной оси отложены торговые дни ( $k$ ), по вертикальной – величина портфеля.

Рис. 10



Значение рыночного портфеля на конец рассматриваемого периода составило 0,72, а виртуального инвестиционного портфеля – 3,54. Используя торговую стратегию на основе нейронной сети карт самоорганизации, мы смогли в значительной степени превзойти динамику рынка. Однако на графике видно, что только в периоды падений и кризисов фондового рынка наша модель демонстрирует хорошие результаты. Резкий рост виртуального инвестиционного портфеля на графике соответствует краху доткомов в начале 2000-х гг. и мировому финансовому кризису 2008 года. В тоже время в период стабильности и устойчивого роста фондового рынка виртуальный инвестиционный портфель показывает отрицательную динамику. Это говорит о том, что в периоды роста и относительно спокойной ситуации на рынке (бокового тренда) наша сеть неэффективна, а, значит, не может воспроизводить модель принятия решений участниками рынка.

Для того чтобы оптимизировать работу нашей искусственной нейронной сети в долгосрочном периоде, мы проведем ещё одну модификацию модели. На этот раз мы усложним алгоритм оптимизации карт самоорганизации с помощью сети Хакена. Герман Хакен – немецкий учёный, который в своей работе (Хакен, 2001) изложил синергетический подход к

организации работы головного мозга человека. Нейронная сеть, которую Хакен описывает в своей книге, была предложена им для распознавания образов, однако мы попробуем применить её для оптимизации работы карт самоорганизации в долгосрочном периоде.

Процесс работы сети Хакена выглядит следующим образом  
(Выражение 6):

$$q^* = q + \sum_{k=1}^M \lambda_k v_k^T q v_k + B \sum_{k=1}^M (v_k^T q)^2 (v_k^T q) v_k + C(q^T q)q$$

Где,

$q$  – это вектор, который оптимизируется сетью. Его исходное значение – это искусственно зашумлённый исходный вектор, состоящий из  $M$  элементов. В качестве вектора  $q$  мы будем брать наш исходный вектор  $X$ , состоящий из пяти логарифмированных значений доходности индекса Dow Jones с лагом в два дня. Значение пятого элемента вектора будет всегда равно нулю – так мы будем его зашумлять.

$q^*$  – восстановленный вектор, который получается в результате работы сети Хакена,

$v$  – матрица из  $k$  столбцов, являющаяся библиотекой априорных знаний.

Библиотека априорных знаний – это база знаний, с которой сеть Хакена сопоставляет предъявляемый ей образ и пытается «привести» этот образ к одному из уже содержащихся в библиотеке. Таким образом, принцип работы сети Хакена основан на ассоциативной памяти, который широко используется в работе головного мозга человека. В качестве библиотеки априорных знаний мы будем использовать векторы-отображения исходного вектора  $X$ , полученные после обучения.

$\lambda$  – коэффициент обучения сети,

$B$  и  $C$  – параметры, влияющие на скорость обучения и сходимость сети Хакена.

Результаты работы карт самоорганизации с использованием сети Хакена на долгосрочном периоде наблюдений представлены на Рис. 11 (по горизонтальной оси отложены торговые дни ( $k$ ), по вертикальной – величина портфеля). Архитектура сети и процесс обучения на максимуме и минимуме остались прежними, а торговое правило было немного изменено. Мы вставляли в длинную позицию, если абсолютное значение прогноза сети было больше или равно логарифмированному значению доходности индекса Dow Jones в предпрогнозный день. В противном случае мы занимали короткую позицию.

Формально наше торговое правило выгляди так (Выражение 7):

$$G_k = \begin{cases} r_k & \text{if } \zeta_k \geq r_{k-1} \\ -r_k & \text{otherwise} \end{cases}$$

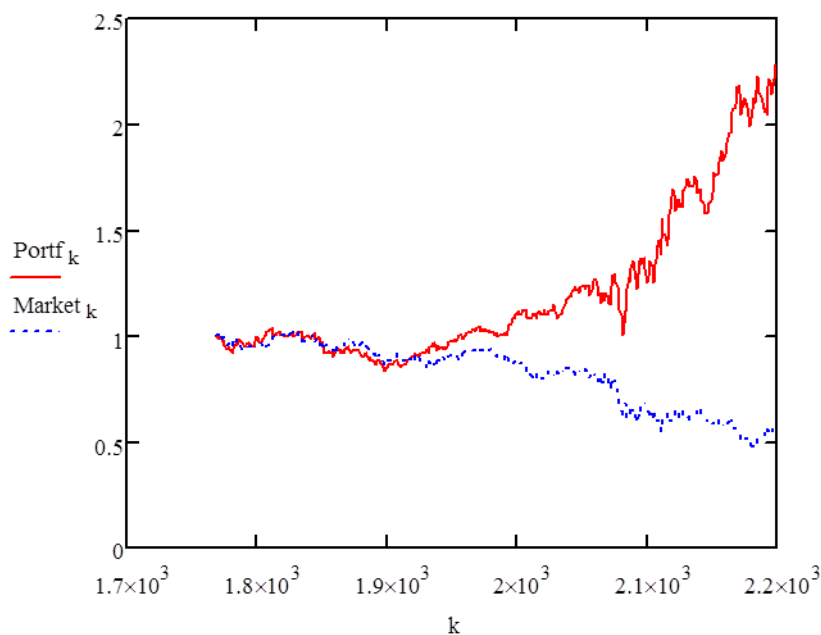
Где,

$G_k$  - логарифмированная доходность виртуального инвестиционного портфеля в торговый день  $k$ ,

$r_k$  – логарифмированная доходность индекса Dow Jones в торговый день  $k$ ,

$\zeta_k$  – скалярное значение прогноза нейронной сети для торгового дня  $k$ .

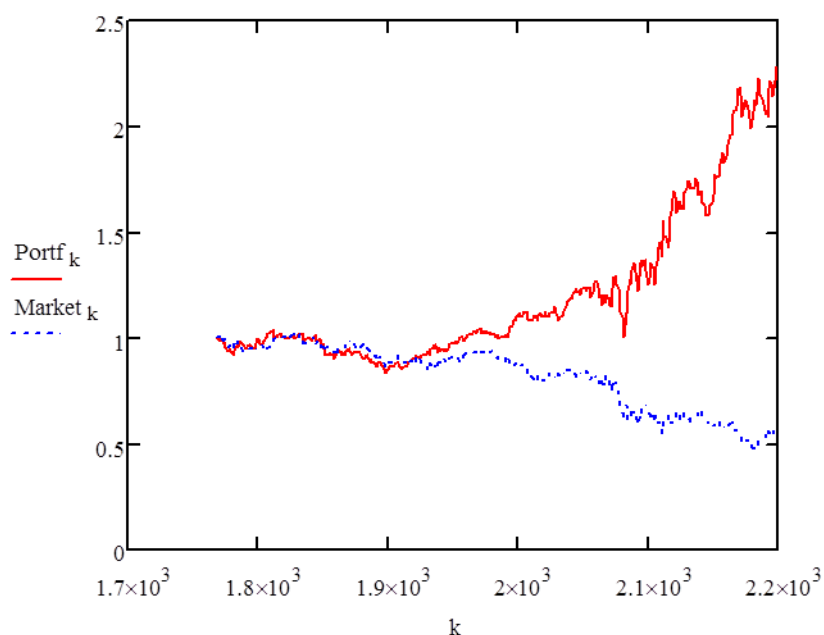
Рис. 11



Значение рыночного портфеля на конец рассматриваемого периода составило 0,55, а виртуального инвестиционного портфеля – 3,25. Если сравнивать эти данные с результатами, представленными на Рис. 10 (работа сети до внедрения синергетической сети Хакена в модель), то они окажутся скромнее: тогда значение виртуального инвестиционного портфеля составило 3,54. Однако следует отметить, что это обусловлено тем, что практически весь рост портфеля на Рис. 10 был обеспечен хорошей игрой на коротких позициях в кризисное время 2008 года.

В свою очередь, модель с использованием сети Хакена не столь эффективна в период краха фондового рынка (короткий период с 27 мая 2007 года по 31 марта 2009 года), что продемонстрировано на Рис. 12. По горизонтальной оси отложены торговые дни ( $k$ ), по вертикальной – величина портфеля.

Рис. 12



Значение рыночного портфеля на конец торгового периода составляет 2,28, в то время как значение виртуального инвестиционного портфеля на Рис.9 – 2,44 (работа модели в острый период кризиса без использования сети Хакена).

Если мы сравним общую динамику виртуального инвестиционного портфеля с использованием сети Хакена и без неё на длинном периоде наблюдений с 30 июня 2000 года по 31 марта 2009 года (Рис. 10 и Рис. 11), то станет очевидно, что применение сети Хакена в нашей модели даёт более ровную положительную динамику на всём торговом периоде.

Таким образом, полученные результаты с использованием сети Хакена позволяют говорить о том, что при такой спецификации наша модель может не только эффективно прогнозировать рынок в период катастрофических падений, но и адаптироваться к различным состояниям фондового рынка. С другой стороны, это также свидетельствует о том, что модель с достаточной степенью достоверности воспроизводит механизм принятия решений участниками рынка, а это и было главной задачей данной работы.

В качестве дальнейшего развития исследования карт самоорганизации предполагается тестирование данной модели на ещё более длительном промежутке времени, а также на торговых данных после 2009 – когда фондовый рынок предположительно в очередной раз изменил режим своего функционирования.

### **Заключение**

В рамках данной работы мы пытались прогнозировать динамику американского фондового рынка в период мирового финансового кризиса. Для этой цели мы использовали методы искусственных нейронных сетей. За основу модели были взяты карты самоорганизации (сеть Кохонена), а в дальнейшем, базируясь на первых прогнозных результатах, мы модифицировали модель с использованием метода главных компонент, изменением процесса обучения и внедрения синергетической нейронной сети Хакена.

Полученные эмпирические результаты (динамика виртуального инвестиционного портфеля) демонстрируют, что карты самоорганизации могут быть эффективно использованы для прогнозирования рынка в период глубоких падений. Более того, модифицированная модель с использованием

сети Хакена позволяет получать хорошие результаты и в долгосрочной перспективе, при отсутствии резких, ярко выраженных колебаний рынка (как вниз, так и вверх).

Более важный результат, чем потенциальный инвестиционный успех торговой стратегии, основанной на использовании карт самоорганизации, заключается в том, что искусственные нейронные сети могут с достаточной степенью точности воспроизводить механизмы поведения и принятия решений участниками фондового рынка – только в случае успеха подобной имитации наша модель была бы успешна в инвестиционном плане.

Дальнейшие исследования в этой области имеет смысл сосредоточить на анализе функционирования искусственных нейронных сетей на различных временных сегментах фондового рынка, а также на других видах финансовых рынков (в частности, валютном).

## Список литературы

1. Круглов В.В., Борисов В.В. Искусственные нейронные сети: Теория и практика. – М.: Горячая линия-Телеком, 2002 – 382 с.: ил.
2. Рубцов Б.Б. Мировые рынки ценных бумаг. – М.: «Издательство «Экзамен», 2002. – 448 с.
3. Евстигнеев В.Р. Прогнозирование доходности на рынке акций. – М.: Маросейка, 2009. – 192 с.
4. Хайкин С. Нейронные сети: полный курс, 2е издание. : Пер. с англ. М. Издательский дом Вильямс", 2006 – 1104 с.: ил.
5. Хакен Г. Принципы работы головного мозга: Синергетический подход к работе мозга, поведению и когнитивной деятельности. – М.: ПЭР СЭ, 2001 – 351 с.
6. Bishop C.M. Neural Networks for Pattern Recognition. Oxford University Press, 1995 – 483 p.
7. Hyvärinen A., Oja E. Independent Component Analysis: Algorithms and Applications//Neural Networks, 13(4-5):411-430, 2000.
8. Jolliffe I.T. Principal Component Analysis, Springer-Verlag (2nd Ed.), 2002.
9. Kohonen T. "Self-organized formation of topologically correct feature maps", Biological Cybernetics, 1982, vol. 43, p. 5969.
10. Kohonen T. "The self-organizing map", Proceedings of the Institute of Electrical and Electronics Engineers, 1990, vol. 78, p. 1464-1480.
11. Kohonen T. "Exploration of very large databases by self-organizing maps", 1997 Interactional Conference on Neural Networks, 1997, vol. 1, p. PL1-PL6, Houston.
12. Kröse B., van der Smagt P. An Introduction To Neural Networks, Eight Edition, November 1996.